

Régression Logistique Polytomique

Variable dépendante à K ($K > 2$) modalités

Ricco RAKOTOMALALA



PLAN

1. Régression logistique multinomiale
2. Variable dépendante ordinale (1)
3. Variable dépendante ordinale (2)

Les fichiers XLS associés à ce support sont disponibles en ligne

http://eric.univ-lyon2.fr/~ricco/cours/slides/multinomial_logistic_regression.xls

http://eric.univ-lyon2.fr/~ricco/cours/slides/ordinal_logistic_regression.xls



Régression logistique multinomiale

La variable dépendante est nominale à K modalités

c.-à-d. Les modalités ne sont pas ordonnées
ou On ne veut pas tenir compte d'un éventuel ordonnancement

LOGITS par rapport à une modalité de référence



Modèle probabiliste et vraisemblance

La distribution multinomiale

Objectif : Modéliser la probabilité d'appartenance d'un individu à une catégorie « k »

$$\pi_k(\omega) = P[Y(\omega) = y_k / X(\omega)]$$

Avec toujours la
contrainte

$$\sum_k \pi_k(\omega) = 1$$

Vraisemblance : On s'appuie sur le modèle multinomial

$$L = \prod_{\omega} [\pi_1(\omega)]^{y_1(\omega)} \times \dots \times [\pi_K(\omega)]^{y_K(\omega)}$$

avec

$$y_k(\omega) = 1 \text{ ssi } Y(\omega) = y_k$$

C'est bien une généralisation du modèle binomial

Stratégie de modélisation

On va **modéliser (K-1) rapports de probabilités** c.-à-d. **Prendre une modalité comme référence** (ex. la dernière), **et exprimer (K-1) LOGIT par rapport à cette référence** (ex. les « non-malades » à opposer à différentes catégories de maladies)

La dernière probabilité, appartenance à la K-ème catégorie, est déduite des autres

$$\pi_K(\omega) = 1 - \sum_{k=1}^{K-1} \pi_k(\omega)$$



Ré-écriture du LOGIT

Et obtention des probabilités d'appartenance

On écrit (K-1) équation
LOGIT :

$$LOGIT_k(\omega) = \ln \left[\frac{\pi_k(\omega)}{\pi_K(\omega)} \right] = a_{0,k} + a_{1,k} X_1(\omega) + \dots + a_{J,k} X_J(\omega)$$

On en déduit les (K-1)
probabilités d'affectation

$$\pi_k(\omega) = \frac{e^{LOGIT_k(\omega)}}{1 + \sum_{k=1}^{K-1} e^{LOGIT_k(\omega)}}$$

Et la dernière \rightarrow

$$\pi_K(\omega) = 1 - \sum_{k=1}^{K-1} \pi_k(\omega)$$

On peut vérifier que

$$\sum_{k=1}^K \pi_k(\omega) = 1$$

La règle d'affectation est le
très classique

$$Y(\omega) = y_{k^*} \Leftrightarrow y_{k^*} = \arg \max_k [\pi_k(\omega)]$$



Estimation des paramètres

Estimateur du maximum de vraisemblance

La log-vraisemblance à maximiser

$$LL = \sum_{\omega} y_1(\omega) \ln \pi_1(\omega) + \dots + y_K(\omega) \ln \pi_K(\omega)$$

Il y a $(K-1) \times (J+1)$ paramètres à estimer. On peut s'appuyer de nouveau sur la méthode de Newton-Raphson.

Vecteur gradient
 $(K-1) \times (J+1) \times 1$

$$G = \begin{pmatrix} G_1 \\ \vdots \\ G_{K-1} \end{pmatrix}$$

G_k est de dim. $(J+1 \times 1)$, avec pour chaque case

$$[g_{k,j}] = \sum_{\omega} x_j(\omega) \times [y_k(\omega) - \pi_k(\omega)]$$

Matrice hessienne
 $(K-1) \times (J+1) \times (K-1) \times (J+1)$

$$H = \begin{pmatrix} H_{11} & & H_{1,K-1} \\ & \ddots & \\ & & H_{K-1,K-1} \end{pmatrix}$$

$H_{i,j}$ est de dim. $(J+1 \times J+1)$, définie par

$$H_{ij} = \sum_{\omega} \pi_i(\omega) \times [\delta_{ij}(\omega) - \pi_j(\omega)] \times x(\omega) x'(\omega)$$

avec $x(\omega) = (1, X_1(\omega), \dots, X_J(\omega))$

et $\delta_{ij}(\omega) = \begin{cases} 1, & \text{si } i = j \\ 0, & \text{si } i \neq j \end{cases}$



Un exemple

Choix Marque = f (sexe : femme, age) – 735 observations

Marque = {Petit prix [1], Enseigne [2], Référence du marché [3]}

Petit prix vs. Référence

$$LOGIT_1 = 22.72 - 0.47 \times F - 0.69 \times age$$

Les femmes ont moins tendance à faire confiance à la marque petit prix (par rapport à la référence)

Plus l'âge augmente, moins la personne fait le choix de la marque petit prix (par rapport à la référence)

Enseigne vs. Référence

$$LOGIT_2 = 10.95 + 0.06 \times F - 0.32 \times age$$

Classement (F = 1, age = 35)

$$LOGIT_1 = 22.72 - 0.47 \times 1 - 0.69 \times 35 \approx -1.75$$

$$LOGIT_2 = 10.95 - 0.06 \times 1 - 0.32 \times 35 \approx -0.11$$

Probabilités d'appartenance

$$\pi_1 = \frac{e^{-1.75}}{1 + [e^{-1.75} + e^{-0.11}]} = 0.08$$

$$\pi_2 = \frac{e^{-0.11}}{1 + [e^{-1.75} + e^{-0.11}]} = 0.43$$

$$\pi_3 = 1 - (0.08 + 0.43) = 0.49$$



La personne fera plus volontiers le choix de la marque 3 c.-à-d. la marque référence du marché



Calculer les LOGIT

Autres que par rapport à la référence

Comparer un groupe à un autre
c.-à-d. calculer

$$\begin{aligned} LOGIT_{i,j} &= \ln \frac{\pi_i}{\pi_j} = \ln \frac{\pi_i / \pi_K}{\pi_j / \pi_K} \\ &= \ln \frac{\pi_i}{\pi_K} - \ln \frac{\pi_j}{\pi_K} = LOGIT_i - LOGIT_j \end{aligned}$$

Confronter « Petit prix [1] » et « Enseigne [2] »

Petit prix vs. Référence

$$LOGIT_1 = 22.72 - 0.47 \times F - 0.69 \times age$$

Enseigne vs. Référence

$$LOGIT_2 = 10.95 + 0.06 \times F - 0.32 \times age$$

Petit prix vs. Enseigne

$$LOGIT_{1,2} = 11.77 - 0.52 \times F - 0.37 \times age$$

Les femmes ont moins tendance à faire confiance à la
marque petit prix (par rapport à « enseigne »)

Plus l'âge augmente, moins la personne fait le choix de la
marque petit prix (par rapport à « enseigne »)



Évaluation globale de la régression

Au delà des pseudo-R² et Matrice de confusion - Test du rapport de vraisemblance

Principe, toujours le même, comparer le modèle avec le modèle trivial composé de la seule constante (dans chaque équation LOGIT)

$$\hat{a}_{0,k} = \ln \frac{n_k}{n_K}$$

Statistique du test

$$LR = -2 \ln \frac{L(0)}{L(M)} = -2 \times LL(0) - [-2LL(M)]$$

Distribution

$$LR \equiv \chi^2 [(n - (1) \times (K - 1)) - (n - (J + 1) \times (K - 1))] \equiv \chi^2 [J \times (K - 1)]$$

| | | |
|----------------------------------|-------------|----------|
| Predicted attribute | brand | |
| Ref. value | M_Reference | |
| Number of examples | 735 | |
| Model Fit Statistics | | |
| Criterion | Intercept | Model |
| AIC | 1595.792 | 1417.941 |
| SC | 1604.991 | 1445.541 |
| -2LL | 1591.792 | 1405.941 |
| Model Chi ² test (LR) | | |
| Chi-2 | 185.8502 | |
| d.f. | 4 | |
| P(> Chi-2) | 0.0000 | |
| R ² -like | | |
| McFadden's R ² | 0.1168 | |
| Cox and Snell's R ² | 0.2234 | |
| Nagelkerke's R ² | 0.2524 | |

$$LR = 1591.762 - 1405.941 = 185.85$$

$$p - value < 0.0001$$

Les variables prédictives emmènent significativement de l'information dans l'explication des valeurs prises par la variable dépendante.

Pseudo-R² :
 = 0 → modèle inutile
 =1 → modèle parfait



Évaluation individuelle des coefficients (dans chaque LOGIT)

Test de Wald

Tester dans une équation LOGIT : le coefficient est significativement différent de 0 ?

$$\begin{cases} H_0 : a_{j,k} = 0 \\ H1 : a_{j,k} \neq 0 \end{cases}$$

Statistique du test de Wald
Elle suit une loi du KHI-2 à 1 d.d.!

$$W_{j,k} = \left(\frac{\hat{a}_{j,k}}{\hat{\sigma}_{\hat{a}_{j,k}}} \right)^2$$

La matrice de Variance-covariance, inverse de la matrice Hessienne, fournit les estimations des écarts type.

| Class.Value | M_PetitPrix.1 | | | | M_Enseigne.2 | | | | |
|-------------|---------------|-----------|---------|-------|--------------|-----------|---------|---------|---------|
| | Pred.Att. | Coef. | Std.Err | Wald | p-value | Coef. | Std.Err | Wald | p-value |
| intercept | | 22.721397 | | - | - | 10.946741 | - | - | - |
| femme | | -0.465941 | 0.2261 | 4.247 | 0.0393 | 0.057873 | 0.1964 | 0.08681 | 0.7683 |
| age | | -0.685908 | 0.0626 | 120 | 0.0000 | -0.317702 | 0.0440 | 52.12 | 0.0000 |

Calcul de la matrice Hessienne

Sortie du logiciel

| Hessian | Intercept.1 | Femme.1 | Age.1 | Intercept.2 | Femme.2 | Age.2 |
|-------------|-------------|----------|-----------|-------------|----------|-----------|
| Intercept.1 | 124.55 | 75.15 | 3994.78 | -84.52 | -51.68 | -2688.56 |
| Femme.1 | 75.15 | 75.15 | 2405.87 | -51.68 | -51.68 | -1641.70 |
| Age.1 | 3994.78 | 2405.87 | 128479.71 | -2688.56 | -1641.70 | -85734.53 |
| Intercept.2 | -84.52 | -51.68 | -2688.56 | 173.70 | 112.66 | 5716.17 |
| Femme.2 | -51.68 | -51.68 | -1641.70 | 112.66 | 112.66 | 3704.70 |
| Age.2 | -2688.56 | -1641.70 | -85734.53 | 5716.17 | 3704.70 | 188915.35 |

Détails calcul Wald

$$\hat{\sigma}^2_{\hat{a}_{femme,1}} = 0.0511$$

$$\hat{\sigma}_{\hat{a}_{femme,1}} = 0.2261$$

$$W_{femme,1} = \left(\frac{-0.466}{0.2261} \right)^2 = 4.247$$

$$p - value_{femme,1} = 0.0393$$

$$\hat{\Sigma} = H^{-1}$$

| INV--Var.Covar | Intercept.1 | Femme.1 | Age.1 | Intercept.2 | Femme.2 | Age.2 |
|----------------|-------------|---------|---------|-------------|---------|---------|
| Intercept.1 | 4.2355 | -0.0572 | -0.1284 | 1.6579 | -0.0347 | -0.0480 |
| Femme.1 | -0.0572 | 0.0511 | 0.0008 | -0.0265 | 0.0260 | 0.0003 |
| Age.1 | -0.1284 | 0.0008 | 0.0039 | -0.0485 | 0.0005 | 0.0014 |
| Intercept.2 | 1.6579 | -0.0265 | -0.0485 | 2.2295 | -0.0396 | -0.0653 |
| Femme.2 | -0.0347 | 0.0260 | 0.0005 | -0.0396 | 0.0386 | 0.0004 |
| Age.2 | -0.0480 | 0.0003 | 0.0014 | -0.0653 | 0.0004 | 0.0019 |

| Racine(Variance) | 2.0580 | | | | | |
|------------------|--------|--------|--------|--------|--------|--------|
| | | 0.2261 | | | | |
| | | | 0.0626 | | | |
| | | | | 1.4932 | | |
| | | | | | 0.1964 | |
| | | | | | | 0.0440 |



Évaluation globale des coefficients (dans l'ensemble des LOGIT)

Généralisation du test de Wald sur plusieurs coefficients

Tester : la variable joue un rôle dans le problème traité ?

$$\begin{cases} H_0 : \forall k, a_{j,k} = 0 \\ H_1 : \exists k, a_{j,k} \neq 0 \end{cases}$$

Le coefficient de la variable j est-il égal à zéro dans toutes les équations ?

Statistique du test de Wald, elle suit une loi du KHI-2 à (K-1) d.d.l

$$W_j = \hat{a}'_j \hat{\Sigma}_j^{-1} \hat{a}_j \cong \chi^2(K-1)$$

avec $\hat{a}_j = \begin{pmatrix} \hat{a}_{j,1} \\ \hat{a}_{j,2} \\ \vdots \\ \hat{a}_{j,K-1} \end{pmatrix}_{(K-1) \times 1}$

et $\hat{\Sigma}_j$
 $(K-1) \times (K-1)$

Est la partie de la matrice de variance co-variance relative au coefficient de la variable Xj

Rappel – Mat. Var.Covar.

| INV--Var.Covar | Intercept.1 | Femme.1 | Age.1 | Intercept.2 | Femme.2 | Age.2 |
|----------------|-------------|---------|---------|-------------|---------|---------|
| Intercept.1 | 4.2355 | -0.0572 | -0.1284 | 1.6579 | -0.0347 | -0.0480 |
| Femme.1 | -0.0572 | 0.0511 | 0.0008 | -0.0265 | 0.0260 | -0.0003 |
| Age.1 | -0.1284 | 0.0008 | 0.0039 | -0.0485 | 0.0005 | 0.0014 |
| Intercept.2 | 1.6579 | -0.0265 | -0.0485 | 2.2295 | -0.0396 | -0.0653 |
| Femme.2 | -0.0347 | 0.0260 | 0.0005 | -0.0396 | 0.0386 | 0.0004 |
| Age.2 | -0.0480 | -0.0003 | 0.0014 | -0.0653 | 0.0004 | 0.0019 |

Rappel – Coef.(femme) LOGIT 1 et 2

$$\hat{a}_{femme} = \begin{pmatrix} -0.466 \\ +0.058 \end{pmatrix}$$

$$\hat{\Sigma}_{femme} = \begin{pmatrix} 0.0511 & 0.0260 \\ 0.0260 & 0.0386 \end{pmatrix}$$



$$\hat{\Sigma}_{femme}^{-1} = \begin{pmatrix} 29.75 & -20.03 \\ -20.03 & 39.41 \end{pmatrix}$$



$$W_{femme} = 7.6704$$

Avec un $\chi^2(2) \rightarrow p\text{-value} = 0.0216$
À 5%, la variable est globalement significative, on doit la conserver.



Interprétation des coefficients

Odds-ratio – Marque = f(femme)

Croisement Marque vs. Femme

| Nombre de brand | femme | 0 | Total |
|-----------------|-------|-----|-------|
| brand | 1 | 0 | Total |
| M_PetitPrix | 115 | 92 | 207 |
| M_Enseigne | 208 | 99 | 307 |
| M_Reference | 143 | 78 | 221 |
| Total | 466 | 269 | 735 |

| Odds(Référence) | | |
|-----------------|----------|----------|
| M_PetitPrix | 0.804196 | 1.179487 |
| M_Enseigne | 1.454545 | 1.269231 |

| Odds-Ratio (Référence) | |
|------------------------|----------|
| M_PetitPrix | 0.681818 |
| M_Enseigne | 1.146006 |

Résultats de la régression logistique

| Class. Value | M_PetitPrix | | | | M_Enseigne | | |
|--------------|-------------|---------|-------|---------|------------|---------|--------|
| | Coef. | Std.Err | Wald | p-value | Coef. | Std.Err | Wald |
| constant | 0.16508 | - | - | - | 0.238411 | - | - |
| femme | -0.38299 | 0.1984 | 3.725 | 0.0536 | 0.136282 | 0.1863 | 0.5349 |



$$OR_j = e^{\hat{a}_j} \quad \text{---} \rightarrow$$

| Odds-Ratio | Femme |
|-------------|---------|
| M_PetitPrix | 0.68182 |
| M_Enseigne | 1.14601 |

Pour une variable nominale (0/1)

- L'interprétation en termes de surcroît de risque (odds-ratio) reste valable
- Mais par rapport à la modalité de référence (ex. une femme a 0.6818 fois plus de chances qu'un homme de préférer la marque « petit prix » à la marque « référence »... hum!!! La lecture est difficile à ce stade...).

Pour les autres types de variables (nominale à + de 2 catégories, ordinale, continue), les interprétations vues pour la rég.logistique binaire restent valables, mais toujours par rapport à la modalité de référence.

Remarque : L'exponentielle des constantes des régression de la régression s'interprètent comme des ODDS (ex. Pour la modalité « Petit prix » → $EXP(0.16508) = 1.179487$ c.-à-d. chez les hommes [femme = 0], on a 1.17 fois plus de chances de choisir la marque petit prix que la marque de référence).



Régression logistique ordinaire (1)

La variable dépendante est ordinaire à K modalités
Plus que la prédiction, c'est l'interprétation des coefficients qui importe

LOGITS adjacents



Définition des LOGITS adjacents

Principe :

Calculer le LOGIT du passage d'une catégorie à l'autre

(K-1) équations LOGIT sont calculés → (K-1) x (J+1) paramètres à estimer

$$\left\{ \begin{array}{l} LOGIT_1(\omega) = \ln \left[\frac{\pi_1(\omega)}{\pi_2(\omega)} \right] = a_{0,1} + a_{1,1}X_1(\omega) + \dots + a_{J,1}X_J(\omega) \\ \dots \\ LOGIT_{K-1}(\omega) = \ln \left[\frac{\pi_{K-1}(\omega)}{\pi_K(\omega)} \right] = a_{0,K-1} + a_{1,K-1}X_1(\omega) + \dots + a_{J,K-1}X_J(\omega) \end{array} \right.$$

Même idée que le modèle multinomial, sauf que la catégorie de référence change à chaque étape.

On évalue le passage de la modalité (k) à (k-1) [moins bonne]

Cette écriture peut être vue comme une ré-interprétation du modèle multinomial !!!

$$\left\{ \begin{array}{l} \ln \left[\frac{\pi_2(\omega)}{\pi_1(\omega)} \right] = -LOGIT_1(\omega) \\ \ln \left[\frac{\pi_3(\omega)}{\pi_1(\omega)} \right] = -LOGIT_2(\omega) - LOGIT_1(\omega) \\ \dots \\ \ln \left[\frac{\pi_K(\omega)}{\pi_1(\omega)} \right] = -LOGIT_{K-1}(\omega) - \dots - LOGIT_2(\omega) - LOGIT_1(\omega) \end{array} \right.$$

On peut utiliser les résultats du modèle multinomial pour estimer les paramètres.

Les évaluations et les tests de significativité sont les mêmes.

Voyons ce qu'il en est pour l'interprétation des coefficients.



Un exemple

Qualité du vin = f (soleil, pluie) – Données centrées réduites

| | |
|---------|--------|
| -2LL(0) | 74.647 |
| -2LL(M) | 33.635 |
| LR | 41.012 |
| d.f. | 4 |
| p-value | 0.0000 |

Modèle
globalement
significatif

Coefficients des LOGITS

| Sans contraintes | | | | | | | | |
|------------------|---------------|---------|-------|---------|----------------|---------|-------|---------|
| | bad => medium | | | | medium => good | | | |
| | Coef. | Std.Err | Wald | p-value | Coef. | Std.Err | Wald | p-value |
| Intercept | 1.655 | - | - | - | -1.706 | - | - | - |
| soleil | 4.051 | 1.982 | 4.178 | 0.0409 | 2.478 | 1.128 | 4.827 | 0.0280 |
| pluie | -1.702 | 1.038 | 2.689 | 0.1010 | -1.561 | 1.024 | 2.327 | 0.1272 |

Comment lire ces résultats ?

bad → medium

Le nombre de jours d'ensoleillement augmente de 1 é.t.
→ le LOGIT augmente de 4.051



ODDS-RATIO = $\exp(4.051) = 57.5$

Il y a 57 fois plus de chances que le vin soit « medium » que « bad »

medium → good

Le nombre de jours d'ensoleillement augmente de 1 é.t.
→ le LOGIT augmente de 2.478



ODDS-RATIO = $\exp(2.478) = 11.9$

Il y a 11 fois plus de chances que le vin soit « good » que « medium »



- L'interprétation dépend de la valeur (du niveau) de la variable réponse (Y)
- Lecture difficile dès que le nombre de variables augmente



LOGITS adjacents à coefficients constants

Réduire l'espace des solutions pour une autre (meilleure ?) interprétation des résultats

Introduire contrainte suivante

$$LOGIT_k(\omega) = \ln \left[\frac{\pi_k(\omega)}{\pi_{k+1}(\omega)} \right] = a_{0,k} + a_1 X_1(\omega) + \dots + a_J X_J(\omega)$$

Le surcroît de risque induit par une variable explicative pour passer d'une catégorie à la suivante ne dépend pas du niveau (de la valeur) de la variable dépendante.

Modèle globalement significatif

| | |
|---------|--------|
| -2LL(0) | 74.647 |
| -2LL(M) | 34.252 |
| LR | 40.396 |
| d.f. | 2 |
| p-value | 0.0000 |

Coefficients des LOGITS

| Avec contrainte | | | | |
|----------------------------|--------|---------|-------|---------|
| | Coef. | Std.Err | Wald | p-value |
| Intercept (bad => medium) | 1.287 | - | - | - |
| Intercept (medium => good) | -2.042 | - | - | - |
| soleil | 3.035 | 0.981 | 9.568 | 0.0020 |
| pluie | -1.452 | 0.695 | 4.362 | 0.0368 |

Comment lire ces résultats ?

Les constantes : Lorsque l'on observe la valeur moyenne des explicatives (soleil = 0, pluie = 0, !!! Les variables sont centrées), on a **EXP(1.287) = 3.6** fois plus de chances d'avoir un vin **medium que bad** ; et **EXP(-2.042) = 0.13** plus de chances d'avoir un vin good que medium (ou $1/13 = 7.7$ fois plus de chances d'avoir un vin medium que good).

Les coefficients des variables (ex. Soleil) : Lorsqu'on augmente de 1 écart type l'ensoleillement, on **EXP(3.035) = 20.8** fois plus de chances de passer dans la catégorie supérieure (que l'on soit présentement bad ou medium !!!).

Plus de contraintes → Plus de stabilité : On réduit les écarts type des estimateurs, certaines variables peuvent devenir significatives (ex. pluie : significative à 5% maintenant)



Résultat plus concis, plus lisible

Mais la vision reste locale : on évalue le risque de passer d'un niveau à l'autre



Régression logistique ordinale (2)

La variable dépendante est ordinale à K modalités
Plus que la prédiction, c'est l'interprétation des coefficients qui importe

ODDS-RATIO cumulatifs



Définition des LOGITS cumulatifs

Principe : Calculer le LOGIT d'être au delà ou en deçà du niveau y_k de la variable Y

Définissons la probabilité cumulée

$$P(Y \leq k / X) = \pi_1 + \dots + \pi_k$$

LOGITS cumulatifs

$$LOGIT_k = \ln\left(\frac{P(Y \leq k / X)}{P(Y > k / X)}\right) = \ln\left(\frac{P(Y \leq k / X)}{1 - P(Y \leq k / X)}\right) = \ln\left(\frac{\pi_1 + \dots + \pi_k}{\pi_{k+1} + \dots + \pi_K}\right)$$

(K-1) équations LOGIT sont définis (dans un premier temps)

$$\begin{cases} LOGIT_1(\omega) = a_{0,1} + a_{1,1}X_1(\omega) + \dots + a_{J,1}X_J(\omega) \\ \dots \\ LOGIT_{K-1}(\omega) = a_{0,K-1} + a_{1,K-1}X_1(\omega) + \dots + a_{J,K-1}X_J(\omega) \end{cases}$$

Introduisons de nouveau l'hypothèse : le rôle d'une variable ne dépend pas du niveau de Y

$$LOGIT_k(\omega) = a_{0,k} + a_1X_1(\omega) + \dots + a_JX_J(\omega)$$

- Modèle à Odds ratio cumulatifs proportionnels : **très utilisé** car d'excellente interprétation
- Lien sous-jacent entre les X_j et une variable latente Z (version continue de Y)
- Constantes = log-odds d'être inf. ou égal à la catégorie k lorsque $X_1 = \dots = X_J = 0$ → sorte de paliers
- Les droites LOGIT vs. Explicatives sont donc parallèles, décalées selon les constantes
- (K + J - 1) paramètres à estimer



Probabilités et vraisemblance

Calculer la probabilité de se situer en deçà d'une valeur de Y (pour un individu)

$$P(Y \leq k / X) = \frac{e^{a_{0,k} + a_1 X_1 + \dots + a_J X_J}}{1 + e^{a_{0,k} + a_1 X_1 + \dots + a_J X_J}}$$

Vision globale c.-à-d. situer le positionnement d'un individu sur l'échelle de valeur définie par Y

$$P(Y > k / X) = 1 - P(Y \leq k / X)$$

$$P(Y = k / X) = P(Y \leq k / X) - P(Y \leq k - 1 / X)$$

$$P(Y \leq K / X) = 1$$

} Bien évidemment

La fonction de vraisemblance à maximiser

$$L = \left[\prod_{k=1}^{K-1} \prod_{\omega: Y(\omega)=k} P(Y(\omega) \leq k / X(\omega)) \right] \left[\prod_{\omega: Y(\omega)=K} P(Y(\omega) = K / X(\omega)) \right]$$

--- ➔ Pour obtenir les coefficients

$$(\hat{a}_{0,1}, \dots, \hat{a}_{0,K-1}, \hat{a}_1, \dots, \hat{a}_J)$$



Exemple des Vins

| | |
|---------|--------|
| -2LL(0) | 74.647 |
| -2LL(M) | 34.441 |
| LR | 40.207 |
| d.f. | 2 |
| p-value | 0.0000 |

Modèle
globalement
significatif

Coefficients des LOGIT

| LOGIT cumulatifs proportionnels | | | | |
|---------------------------------|--------|---------|--------|---------|
| | Coef. | Std.Err | Wald | p-value |
| Intercept (<= bad) | -1.427 | - | - | - |
| Intercept (<= medium) | 2.322 | - | - | - |
| soleil | -3.226 | 0.943 | 11.716 | 0.0006 |
| pluie | 1.567 | 0.730 | 4.603 | 0.0319 |

Comment lire ces résultats ?

Classement d'une observation :

Soleil = 1 et pluie = 1

$$LOGIT_{bad} = -1.427 - 3.226 \times 1 + 1.567 \times 1 = -3.086$$

$$\Rightarrow P(Y \leq bad / X) = \frac{e^{-3.086}}{1 + e^{-3.086}} = 0.044$$

$$\rightarrow P(Y = bad / X) = 0.044$$

$$LOGIT_{medium} = 2.322 - 3.226 \times 1 + 1.567 \times 1 = 0.662$$

$$\Rightarrow P(Y \leq medium / X) = \frac{e^{0.662}}{1 + e^{0.662}} = 0.660$$

$$\rightarrow \begin{aligned} P(Y = medium / X) \\ &= 0.660 - 0.044 \\ &= 0.616 \end{aligned}$$

$$\rightarrow P(Y = good / X) = 1 - 0.616 = 0.384$$

Les constantes : Lorsque l'on observe la valeur moyenne des explicatives (soleil = 0, pluie = 0, !!! Les variables sont centrées), on a $EXP(-1.427) = 0.24$ fois plus de chances d'avoir un vin **bad que meilleur que bad {medium ou good}** ; et $EXP(2.322) = 10.2$ fois plus de chances d'avoir un vin inf. ou égal à medium que good.



Exemple des vins (suite)

Coefficients des LOGIT

Comment lire ces résultats ?

| LOGIT cumulatifs proportionnels | | | | |
|---------------------------------|--------|---------|--------|---------|
| | Coef. | Std.Err | Wald | p-value |
| Intercept (<= bad) | -1.427 | - | - | - |
| Intercept (<= medium) | 2.322 | - | - | - |
| soleil | -3.226 | 0.943 | 11.716 | 0.0006 |
| pluie | 1.567 | 0.730 | 4.603 | 0.0319 |

Les coefficients (ex. pour la variable soleil) : Lorsque l'ensoleillement augmente de Δ , tous les LOGIT augmentent de (toutes choses égales par ailleurs)

$$\forall k : LOGIT_k(X_j + \Delta) - LOGIT_k(X_j) = \hat{a}_j \times \Delta$$

En termes d'odds-ratio

$$OR_j = \frac{P(Y \leq k / X_j + \Delta) / P(Y > k / X_j + \Delta)}{P(Y \leq k / X_j) / P(Y > k / X_j)} = e^{\hat{a}_j \times \Delta}$$



Lorsque les jours d'ensoleillement augmentent de 1 é.t., on a $EXP(-3.226) = 0.04$ fois plus de chances d'avoir un vin moins bon qu'il ne l'est (ou mieux, $1/0.04 \approx 25$ fois plus de chances d'améliorer sa qualité).
Ceci quel que soit son niveau de qualité actuel !!!

Pourquoi « proportionnel » ? L'odds-ratio cumulatif, suite à une variation Δ d'une des variables explicatives X_j , est proportionnel à Δ et ne dépend pas du niveau de Y . Le paramètre a_j de la variable est le coefficient de proportionnalité.



Exemple 2 – Hypertension

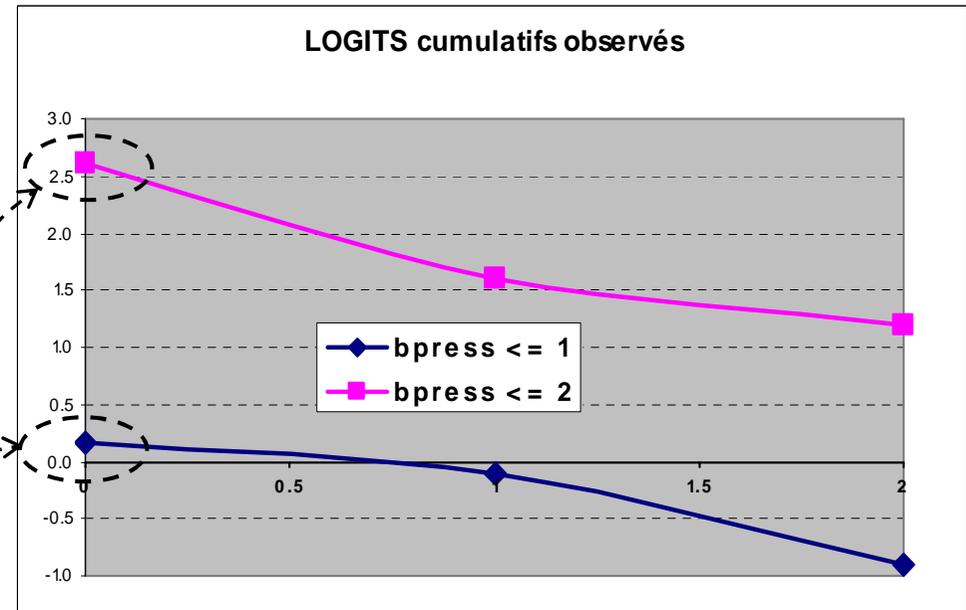
Comprendre les LOGITS cumulatifs proportionnels

Hypertension {0, 1, 2} = f [Surpoids {1, 2, 3}]

| Nombre de bpress | overweight | | | Total |
|------------------|------------|----|-----|-------|
| | 0 | 1 | 2 | |
| 3 | 11 | 13 | 37 | 61 |
| 2 | 63 | 28 | 76 | 167 |
| 1 | 88 | 37 | 46 | 171 |
| Total | 162 | 78 | 159 | 399 |

$$\ln \frac{P(Y \leq 2/0)}{P(Y > 2/0)} = \ln \frac{63+88}{11} = 2.6194$$

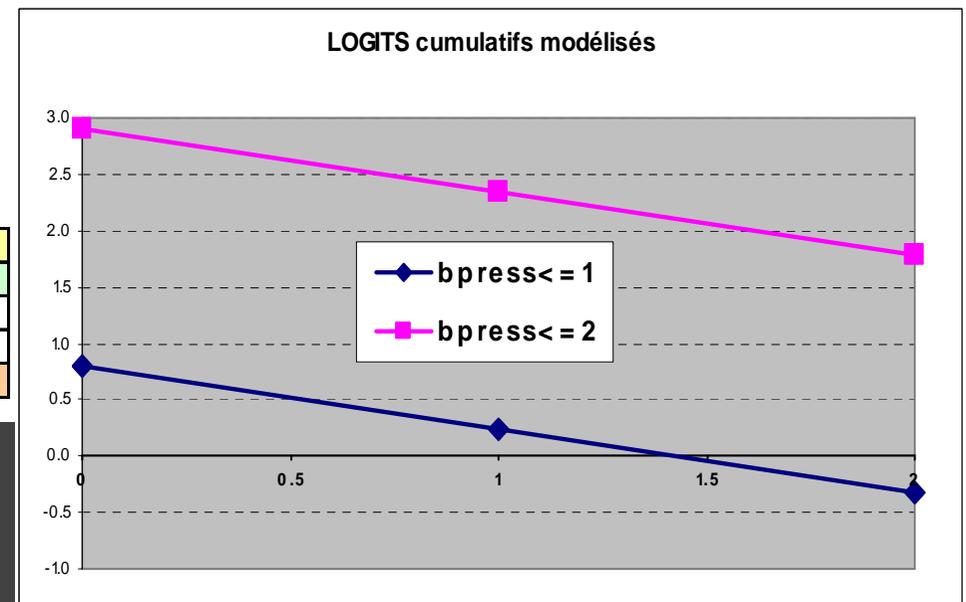
$$\ln \frac{P(Y \leq 1/0)}{P(Y > 1/0)} = \ln \frac{88}{63+11} = 0.1733$$



Hypothèses pour la modélisation : (1) ces courbes sont des droites ; (2) elles sont parallèles.

| | |
|---------|---------|
| -2LL(0) | 809.806 |
| -2LL(M) | 782.286 |
| LR | 27.520 |
| d.f. | 1 |
| p-value | 0.0000 |

| LOGIT cumulatifs proportionnels | | | | |
|---------------------------------|--------|---------|--------|---------|
| | Coef. | Std.Err | Wald | p-value |
| Intercept (<= 1) | 0.805 | - | - | - |
| Intercept (<= 2) | 2.912 | - | - | - |
| overweight | -0.561 | 0.109 | 26.328 | 0.0000 |



- (1) Effet du surpoids sur la tension bien appréhendé
- (2) Ajustement pas très bon (cf. Pseudo-R²)
- (3) On peut tester l'hypothèse « LOGITS parallèles »
(Cf. Score test for proportional odds assumption dans SAS par ex.)
(On pourrait aussi utiliser le test de rapport de vraisemblance)



Bibliographie

En ligne

A. SLAVKOVIC - « STAT 504 - Analysis of discrete data »

http://www.stat.psu.edu/~jglenn/stat504/08_multilog/01_multilog_intro.htm

Très riche avec des exemples sous SAS et R (redirection sur les sites web)

Ouvrages

J.P. NAKACHE et J. CONFAIS - « Statistique Explicative Appliquée », TECHNIP, 2003.

